中国生态农业学报(中英文)
Chinese Journal of Eco-Agriculture
中文核心期刊
中国科技核心期刊
中国精品科技期刊
百种中国杰出学术期刊
中国科学引文数据库源刊

# 基于卷积神经网络的玉米病害小样本识别研究

杨明欣，张耀光，刘涛

引用本文:
杨明欣, 张耀光, 刘涛. 基于卷积神经网络的玉米病害小样本识别研究[J]. 中国生态农业学报(中英文), 2020, 28(12): 1924−1931.

在线阅读 View online: https://doi.org/10.13930/j.cnki.cjea.200375

(向下翻页，阅读全文)

**您可能感兴趣的其他文章**

Articles you may be interested in

基于气候背景的作物种植条件综合评价概念模型及其应用——以内蒙古巴彦淖尔河套灌区为例

Conceptual model based on climate for comprehensive evaluation of crop planting conditions:A case study in Bayannur Hetao Irrigation District in Inner Mongolia

中国生态农业学报(中英文). 2020, 28(11): 1649−1660 https://doi.org/10.13930/j.cnki.cjea.200442

沼液淹没土壤抑制根结线虫及对土壤线虫群落的影响

Effects of soil flooding of biogas slurry on root−knot nematode (*Meloidogyne* spp.) and soil nematode community

中国生态农业学报(中英文). 2020, 28(8): 1249−1257 https://doi.org/10.13930/j.cnki.cjea.200099

化学农药减量化措施对水稻病虫草害发生及产量的影响

The effects of chemical pesticide reduction on the occurrence of diseases, pests, weeds and rice yield

中国生态农业学报(中英文). 2020, 28(12): 1913−1923 https://doi.org/10.13930/j.cnki.cjea.200297

农业景观格局对玉米害虫−捕食性天敌定性食物网结构的影响

Effects of agricultural landscape pattern on qualitative food web structure of corn pest−predatory natural enemies

中国生态农业学报(中英文). 2020, 28(10): 1475−1487 https://doi.org/10.13930/j.cnki.cjea.200021

短距离样点对土壤呼吸空间变异预测精度的影响

Effects of short distance sampling on the prediction accuracy of the spatial variability of soil respiration

中国生态农业学报(中英文). 2020, 28(3): 421−428 https://doi.org/10.13930/j.cnki.cjea.190703

**DOI: 10.13930/j.cnki.cjea.200375**

杨明欣, 张耀光, 刘涛. 基于卷积神经网络的玉米病害小样本识别研究[J]. 中国生态农业学报(中英文), 2020, 28(12): 1924−1931
YANG M X, ZHANG Y G, LIU T. Corn disease recognition based on the Convolutional Neural Network with a small sampling sizeJ]. Chinese Journal of Eco-Agriculture, 2020, 28(12): 1924−1931

# 基于卷积神经网络的玉米病害小样本识别研究*

杨明欣, 张耀光, 刘 涛**

(河北科技大学经济管理学院 石家庄 050018)

**摘 要:** 农作物病害治理对于农作物的产量和品质有着非常重要的影响。本文针对玉米病害人工识别困难、识别过程耗费大量的人力成本和病害数据样本小且分布不均的问题, 提出了一种改进的迁移学习神经网络(Neural Network)的病害识别方法。首先, 采用旋转、翻转等方法对样本图像集进行数据增强; 其次, 通过迁移的 MobileNetV2 模型在玉米病害图像数据集上训练, 利用 Focal Loss 函数改进神经网络的损失函数; 最后, 通过 Softmax 分类方法实现玉米病害图像识别。另外通过试验对比 AlexNet、GooleNet、Vgg16、RestNet34、MobileNetV2 和迁移的 MobileNetV2 这 6 种模型的训练集准确率、验证集准确率、权重、参数数量和运行时间。结果显示, 6 种模型验证集的准确率分别为 93.88%、95.48%、91.69%、97.67%、96.21%和 97.23%, 迁移的 MobileNetV2 的准确率最高, 且权重仅有 8.69 MB。进一步通过混淆矩阵对比了 MobileNetV2 和迁移的 MobileNetV2 两种模型, 迁移的 MobileNetV2 模型识别正确率提升 1.02%, 训练速度减少 6 350 s。本文提出迁移的 MobileNetV2 模型对玉米病害小样本的识别效果最佳, 具备更好的收敛速度与识别能力, 同时能够降低模型的运算量并大幅度缩短识别时间。

**关键词:** 玉米病害; 迁移学习; 小样本; 卷积神经网络; Focal Loss; 混淆矩阵

**中图分类号:** TP183 开放科学码(资源服务)标识码(OSID):

# Corn disease recognition based on the Convolutional Neural Network with a small sampling size*

YANG Mingxin, ZHANG Yaoguang, LIU Tao**

(School of Economics and Management, Hebei University of Science and Technology, Shijiazhuang 050018, China)

**Abstract:** Crop disease management influences yield and quality, yet identifying corn diseases is still difficult. High labor costs, small number of sample, and uneven disease distributions contribute to the difficulty. We propose an improved Convolutional Neural Network (CNN) model based on the transfer learning method for disease identification. The sample image set was enhanced by rotation and roll-over, then the migrated MobileNetV2 model was used to train the image data set for corn diseases. The Focal Loss function was used to improve the neural network loss function, and the Softmax classification method was used for corn disease image recognition. The training set accuracy, validation set accuracy, weight, run time, and the number of parameter in six models were experimentally compared. The verification set accuracy rates were 93.88% (AlexNet), 95.48% (GoogleNet), 91.69% (Vgg16), 97.67% (RestNet34), 96.21% (MobileNetV2), and 97.23% (migrated MobileNetV2). The migrated MobileNetV2 was 97.23% accu-

* 河北省重点研发计划项目(19226417D)和河北省高等学校科学技术重点项目(ZD2019083)资助

** 通信作者: 刘涛, 主要研究方向为信息资源管理和大数据分析建模。E-mail: liutaolunwen@163.com
杨明欣, 主要从事信息管理、信息安全方面的研究。E-mail: ymxspj@163.com

收稿日期: 2020-05-20 接受日期: 2020-09-26

* This study was supported by the Key R&D Program of Hebei Province of China (19226417D) and the Key Science and Technology Project of Higher School of Hebei Province of China (ZD2019083).

** Corresponding author, E-mail: liutaolunwen@163.com

Received May 20, 2020; accepted Sep. 26, 2020

rate and weighed 8.69 MB. Confounding the MobileNetV2 model improved the recognition accuracy by 1.02% and reduced the training speed by 6 350 seconds compared to the unconfounded model. The migrated MobileNetV2 model had the best corn disease recognition ability with a small sampling size; improved convergence speed, reduced model calculations, and greatly improved the recognition time.

**Keywords:** Corn diseases and insect pests; Transfer learning; Small sample; Convolutional Neural Network; Focal Loss; Confusion matrix

近年来，随着物联网、遥感技术、图像识别、云计算等技术在我国农业领域的应用，“智慧农业”[1]应运而生，为解决农业生产、农业经营网络化、农业管理数字化、农业服务精准化提供了技术支撑。智慧农业在农业物联网数据资源的细分和数据挖掘方面尚未有效的开展，在农业生产过程中产生的大量图片、声音等信息未能有效利用，深度学习能够有效地利用这些信息为农业生产过程中病虫害的识别提供理论和技术支持。

传统的机器视觉技术对病虫害识别与预测主要基于纹理颜色等特征，或者基于专家的判断，需要大量的专业知识。在病害种类少、数据样本小的情况下，李冠林等[2]提出了一种基于传统机器学习方法——K-means 聚类算法，实现病斑分割，提取病斑区域的形状、颜色和纹理特征空间的 50 个特征参数，设计支持向量机分类器进行分类识别，对小麦条锈病和叶锈病进行分类识别，训练样本识别率均为 96.67%。针对柑橘红蜘蛛虫害，李震等[3]提出基于 Lab 颜色模型的 K-means 识别，通过 5 个聚类中心的 K-means 聚类法，识别柑橘红蜘蛛虫害的准确率达 100%，识别清晰度低的样本时准确率为 80%。许良凤等[4]在大田开放环境下采集包含圆斑病、小斑病、锈病、褐斑病、红叶病、弯孢霉叶斑病和纹枯病共 7 类玉米叶部病害图像，提取颜色、颜色共生矩阵和颜色完全局部二值模式 3 种特征，并构建相应的支持向量机分类器，提出了各分类器自适应动态权值，分类结果平均识别率为 94.71%，极大地提高了单分类器的识别率；但是也因此加长了识别时间，且这种识别精度也未考虑复杂环境对数据集的影响；该试验的训练样本 270 幅，测试样本为 246 幅。传统的识别方法都是通过将植物叶片从复杂的田间环境分割，再进行小样本训练，容易出现过拟合现象。Turkoğlu 等[5]通过尼康 7200d 相机在土耳其的 Malatya、Bingöl 和 Elazığ 3 个地区采集了 1 965 张病虫害照，使用 AlexNet、VGG16、VGG19、GoogleNet、ResNet50、ResNet101、InceptionV3、InceptionResNetV2 和 SqueezeNet 共 9 种强大的深度神经网络架构的方法检测植物病害，利用预训练的深度模型进行特征提取和进一步微调，用传统的支持向量机(SVM)、极限学习机(ELM)、邻近算法(KNN)进行分类，通过准确率、敏感性、特异性和 F1 评分进行性能评估，结果发现通过 ResNet50 模型和 SVM 分类器的精度得分最高，准确率达 97.86%。

相对于传统的识别方法，卷积神经网络(Convolutional Neural Network, CNN)的出现有效地提高了识别效率和准确性。卷积神经网络从 20 世纪 90 年代的 LeNet[6]开始，经历了 AlexNet[7]、VGG[8]、GoogLeNet[9]和 ResNet[10]等不断升级的模型，网络模型越来越深，越来越复杂，解决了反向传播的梯度消失和爆炸。为提高病虫害识别精度，Mohanty 等[11]对 PlantVillage 项目公开数据的 54 306 幅图片通过 AlexNet 和 GoogLeNet 2 种框架，采用迁移学习的方法对 RGB 图片、灰白图像和叶片分割后图像进行试验对比，发现迁移学习的方法优于从头训练，彩色图像优于分割后的图像；但迁移学习的方法在不同训练集条件下，测试准确率会降低。Wang 等[12]通过卷积神经网络进行训练得到基于图像的植物疾病严重程度的自动评估系统，图像是来自 PlantVillage 数据集中的苹果黑腐病图像集，对比了 VGG16、VGG19、Inception-V3 和 RestNet50 模型的训练精度，得到 VGG16 模型在测试集上的精度达 90.4%。Oppenheim 等[13]通过卷积神经网络在不受控制的光照条件下，通过使用标准的低成本 RGB(红色、绿色和蓝色)传感器拍摄的图像数据集进行测试，并由农业专家[14]进行采集、分类和手工标记选取 2 465 张马铃薯病变斑块图片，将卷积神经网络成功应用于农作物病害的识别，用足够的数据集和显示病害的分类，对马铃薯块茎病害基因进行鉴定，挖掘了卷积神经网络在解决农业病虫害的巨大潜力。

传统的支持向量机等方法鲁棒性不强，在复杂的大田环境下应用效果不佳，而使用卷积神经网络进行病虫害识别是一种有监督学习，需要海量的标签，受限于训练数据集数量少、种类不均匀[15-16]、标签数据匮乏等。基于以上研究成果，本研究设计了一种改进的迁移学习神经网络，通过数据增强的图像数据集进行微调，再将微调所得模型迁移到玉

米病害图像数据集继续训练, 利用 Focal Loss 函数改进神经网络的损失函数, 解决了小样本分布不均带来的误差。通过改进的迁移的 MobileNetV2 模型与常规经典模型进行对比实验, 进一步验证改进的 MobileNetV2 模型的各种性能。

## 1 模型基础知识

### 1.1 MobileNetV2

MobileNetV2 是一种轻量型网络, 由 Google 团队在 2018 年为移动和嵌入式设备提出的高效模型, 它利用一种深度可分离卷积(depthwise separable convolutions, 即 Xception 变体结构)来构建轻量级深度神经网络。与 MobileNetV1 相比, MobileNetV2 准确率更高、模型更小。MobileNetV1 中 Depthwise 部分的卷积核的大部分参数为 0, MobileNetV2 提出了倒残差来代替 Depthwise 的卷积核。相比于 RestNet 中的残差结构, 倒残差只有当步长等于 1, 输入矩阵与输出矩阵的形状相同时才能进行捷径连接。图 1 所示的是倒残差结构, 图 1a 表示 RestNet 中的残差结构, 首先 1×1 卷积核对输入的特征矩阵进行降维, 再通过 3×3 的卷积核进行卷积处理, 最后通过 1×1 的卷积核进行升维; 图 1b 表示 MobileNetV2 中的倒残差结构, 首先 1×1 卷积核对输入的特征矩阵进行升维, 再通过 3×3 卷积核进行 DW 卷积, 最后进行 1×1 卷积核降维。

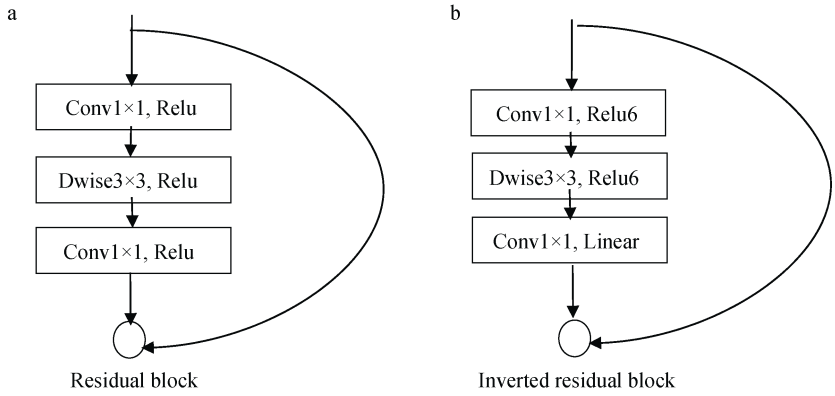


**图 1** 残差网络**(a)**和倒残差网络**(b)**结构图

Fig. 1 Structures of the residual network (a) and the inverted residual network (b)

### 1.2 MobileNetV2 卷积原理

随机选取一张健康玉米 RGB 图片经过预处理成 224×224 大小图片, 通过 MobileNetV2 网络第 1 层卷积通道为 32。输出的大小如公式(1), 其中 $W$ 为输入图片大小, $F$ 为 3×3 卷积核,

$P$ 为填充像素 1, $S$ 为步长 2。输出 feature map 大小 $N$ 为 112。

$$N \leftarrow (W - F + 2P)/S + 1 \tag{1}$$

输出的图片通过 Batch Normalization[17], 使 feature map 满足均值为 0、方差为 1 的分布规律, 进行归一化处理, 通过该方法能够加速网络的收敛并且提高准确率。假设神经网络第 1 层一个 batch 输入为 $X=[x_0, x_1, \cdots, x_m]$, 其中 $x_i$ 为一个样本, $m$ 为样本的数量, 归一化公式如(2)。

$$y_i \leftarrow \gamma \hat{x}_i + \beta \tag{2}$$

$$\hat{x}_i \leftarrow \frac{x_i - \mu_\beta}{\sqrt{\sigma_\beta^2 + \varepsilon}} \tag{3}$$

$$\sigma_\beta^2 \leftarrow \frac{1}{m}\sum_{i=1}^{m}(x_i - \mu_\beta)^2 \tag{4}$$

$$\mu_\beta \leftarrow \frac{1}{m}\sum_{i=1}^{m} x_i \tag{5}$$

式中: $\gamma$、$\beta$ 需要在程序中反向传播学习得到, 输出 $y_i$ 经过 ReLU6 非线性激活函数, 经过该层神经元的激活处理后继续向下传递, ReLU6 激活函数如公式(6)。

$$\mathrm{ReLU6}(X) = \min[\max(x, 0), 6] \tag{6}$$

### 1.3 卷积与倒残差对比

选取的健康玉米 RGB 图片通过第 1 层卷积由 3 个通道变成 32 个通道, 每个通道对应的特征图大小通过公式(1)计算是 112 像素, 特征图如图 2a 所示, 横纵坐标表示像素大小, 每个通道的图片通过 Batch Normalization 进行归一化, 再通过 ReLU6 非线性激活函数进行激活。图中亮度越高表示图片特征越显著。图片通过第 2 层卷积, 采用的是倒残差的卷积方式, 通过公式(1)计算图像大小为 112 像素, 通道由 32 个变成 16 个, 每个通道对应的特征图如图 2b 所示。

图 2a 是原始图片通过第 1 层普通卷积后显示的

特征图, 特征图再经过第 1 次倒残差处理后显示的卷积图如图 2b, 二者对比通过倒残差处理后图片的亮度更高, 处理后的特征趋于明显。

### 1.4　迁移学习

迁移学习[18]是将 ImageNet 数据集上的 120 万张图片进行训练, 获得的权重参数, 应用到玉米病害识别中。通过迁移学习的方法能够快速训练出一个理想的结果, 在数据集小样本标签不够的情况下也能训练出理想的效果。

本试验在迁移 ImageNet 数据集上训练权重参数, 在原网络的基础上再添加一层全连接层, 仅训练最后一层。采用自适应池化(adaptive pooling)取代了平均池化(average pooling), 自适应池化能够根据输入的参数控制输出。为防止过拟合, 通过 Dropout[19]方法随机失活, 修改分类个数为 5。自适应池化后的神经元通过 Dropout 公式(7), 对 Corn 数据集进行训练测试, 通过表 1 进行对比, 结果显示选择 $p$ 概率为 0.2, 测试集准确率最高。

$$w_{\text{test}}^{(l)} = pW^{(l)} \tag{7}$$

式中: $p$ 表示随机失活概率, $w^{(l)}$ 表示自适应池化后的神经元个数。

### 1.5　Focal Loss 函数

分类任务中通常使用 Cross Entropy Loss 交叉熵损失函数(又称为对数似然损失), 在多分类任务中, 经常采用 soft max 激活函数与交叉熵损失函数结合, 交叉熵表示的是实际输出与期望输出的距离, 交叉熵越小二者的概率分布越近。假设概率分布 $p$ 为期望输出, 概率分布 $q$ 为实际输出, $H(p,q)$为交叉熵, 计算公式为:

$$H(p,q) = -\sum_{j=1}^{T} p(x)\log q(x) \tag{8}$$

式中: $T$ 为分类类别数。

由于样本小且不均匀, 会降低准确率。采用 Facal Loss[20]损失函数代替 Cross Entropy Loss 交叉熵损失函数。$a_t$是用来平衡样本数量的, $\gamma$ 相当于惩罚项, 用来控制难分样本的挖掘, 本文中 $a_t$=0.25, $\gamma$ =2。

$$\text{FL}(p) = -a_t[1-p(x)]^{\gamma}\log p(x) \tag{9}$$

## 2　研究方法

### 2.1　构建玉米病害数据集

本文从 AI Challenger 2018 (https://challenger.ai/competition/pdr2018)中选取玉米病害图像作为数据集, 对选取的图像进行数据增强形成 Corn 数据集。该数据集包含健康玉米、玉米灰斑病、玉米锈病、玉米叶斑病、玉米矮花叶病毒病 5 个种类的图像。由于每个种类图片的数量差异大, 训练起来准确率低, 对样本少的数据进行 90°、180°和 270°翻转对图像扩容。对图片进行随机裁剪成 256×256 大小, 再通过中心裁剪成 224×224 大小的图片, 把形状是高度×宽度×通道的像素值范围为[0, 255]的 PIL 库中的 Image 转换成形状是通道×宽度×高度的像素值范围为[0, 1], 进行标准化处理, 效果如图 3。处理后每张图为 224 像素, 5 张图并列展示, 横坐标是[0, 1 120], 纵坐标是[0, 224]。

### 2.2　Corn 数据集

数据增强后的玉米病害数据集如表 2 所示。对玉米病害数据集种类设置标签依次为 0、1、2、3、4。标签为 0 的健康玉米训练集数量 320, 标签 1 的玉米灰斑病训练集数量 358, 标签 0、1 的训练集数量远小于其他训练集的数据, 造成了训练集不平衡, 影响训练的准确率。增强后的数据集样本的数量也是不均匀的, 采用改进的迁移学习方法用 Facal Loss 损失函数代替 Cross Entropy Loss 交叉熵损失函数, 能够解决样本的不平衡性, 从而有效提升准确率, 使模型具有更强的鲁棒性。

如表 3 所示, 把原始的训练集和增强后的数据集通过改进迁移学习的 MobileNetV2 网络进行训练, 训练结果对比发现增强后的标签为 0 的健康玉米的识别准确率从 98.42%提升到 99.38%, 标签为 1 的玉米灰斑病的识别率从 84.56%提升到 89.19%, 训练集整体识别的准确率从 92.77%提升到 94.62%, 通过数据增强的方法有效提升了玉米病害训练集识别准确率。

## 3　结果与分析

采用 Pytorch 框架, GPU 为 GeForce MX110(2GB), 在 Windows 10 环境下配置 CUDA10.2、Python3.6, 构成以 Pytorch 为核心、GPU 加速的卷积神经网络框架。受限于硬件, batch_size 设置为 16, epoch 设置为 10。

试验采用玉米病害小样本 Corn 数据集作为训练集, AlexNet、GooleNet、Vgg16、RestNet34、MobileNetV2、迁移的 MobileNetV2 为对比模型, 用测试集合进行测试并保存权重文件和参数, 测试结果如表 4 所示。结果显示改进的迁移学习的 MobileNetV2 模型比其他模型准确率高, 参数数量最小, 适用于玉米病害识别, 迁移的 MobileNetV2 权重只有 8.69 MB, 而准确率高达 97.23%, 训练时间仅有 2 700 s。

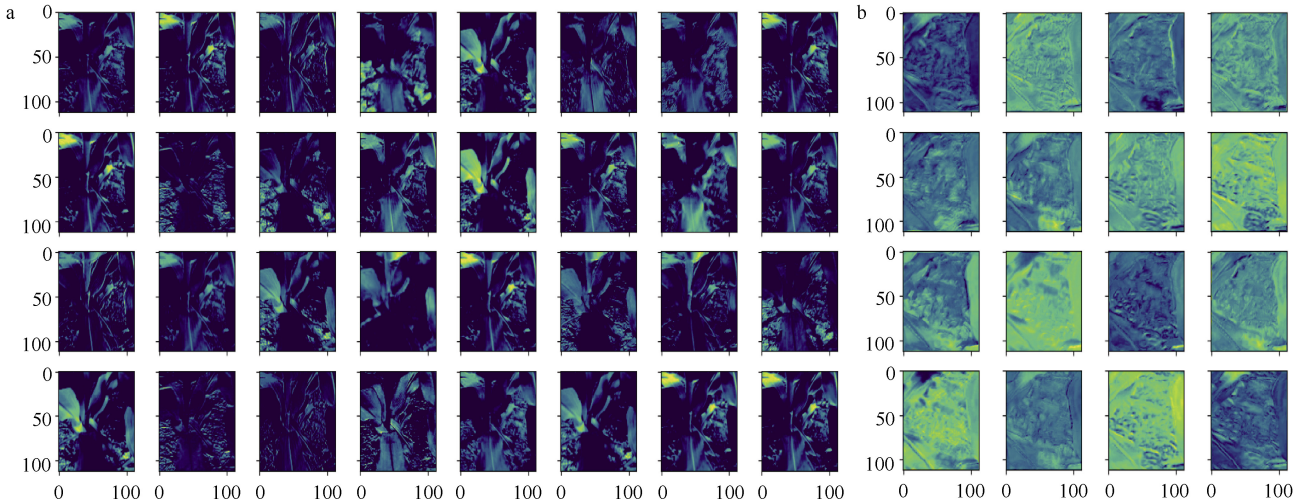


**图 2　第 1 次卷积后形成的 32 个子图(a)和第 1 次残差网络后形成的 16 个子图(b)**

Fig. 2　Thirty-two subgraphs formed after the first convolution (a) and 16 subgraphs formed after the first residual network (b)

**表 1　Dropout 方法中概率 *p* 选择**

Table 1　Probability *p* selection in the Dropout method

| *p* | 训练集准确率 Training set accuracy (%) | 测试集准确率 Valid set accuracy (%) |
|---|---|---|
| 0.1 | 92.52 | 95.77 |
| 0.2 | 93.53 | 97.23 |
| 0.3 | 92.93 | 96.06 |
| 0.4 | 93.01 | 95.48 |
| 0.5 | 92.88 | 95.36 |
| 0.6 | 92.33 | 95.77 |
| 0.7 | 93.31 | 95.59 |
| 0.8 | 91.82 | 95.04 |
| 0.9 | 89.64 | 94.90 |

### 3.1　训练集的混淆矩阵

混淆矩阵用来观察分类结果，是一个 $N\times N$ 的方阵，$N$ 表示类别数。混淆矩阵的行表示真实的类别，列表示预测的类别。

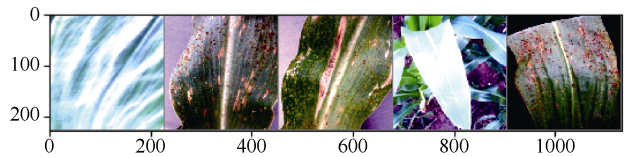


**图 3　预处理后 5 种玉米病害类型的效果图(从左向右依次为玉米矮花叶病毒病、玉米灰斑病、玉米锈病、健康玉米、玉米叶斑病)**

Fig. 3　Pre-processed pictures of maize (from left to right) dwarf mosaic disease, maize gray leaf spots, maize rust, healthy maize and maize leaf spots

**表 2　数据增强后的玉米病害数据集**

Table 2　Maize diseases dataset after data enhancement

| 标签 Label | 标签名称 Label name | 训练集数量 Number of training set | 增强后训练集数量 Number of training sets after enhancement |
|---|---|---|---|
| 0 | 健康玉米 Corn healthy | 320 | 640 |
| 1 | 玉米灰斑病 Maize gray leaf spots | 358 | 716 |
| 2 | 玉米锈病 Maize rust | 838 | 838 |
| 3 | 玉米叶斑病 Maize leaf spots | 669 | 669 |
| 4 | 玉米矮花叶病毒病 Maize dwarf mosaic virus | 815 | 815 |

标签 0-4 的意义见表 2。The meaning of the lable 0-4 is shown in the table 2.

**表 3　5 种玉米病害类型训练集准确率**

Table 3　Train set accuracies of five diseases of maize

| 训练集 Training set | 标签 0 准确率 Label 0 accuracy (%) | 标签 1 准确率 Label 1 accuracy (%) | 标签 2 准确率 Label 2 accuracy (%) | 标签 3 准确率 Label 3 accuracy (%) | 标签 4 准确率 Label 4 accuracy (%) | 总训练集的准确率 Total training set accuracy (%) |
|---|---|---|---|---|---|---|
| 原始 Original | 98.42 | 84.56 | 98.06 | 82.72 | 96.89 | 92.77 |
| 增强 Enhancement | 99.38 | 89.19 | 97.62 | 85.71 | 99.39 | 94.62 |

标签 0-4 的意义见表 2。The meaning of the lable 0-4 is shown in the table 2.

通过迁移的 MobileNetV2 对玉米病害 Corn 数据集中的训练集进行训练, 对训练集的训练结果制作混淆矩阵, 对健康玉米、玉米灰斑病、玉米锈病、玉米叶斑病、玉米矮花叶病毒病, 5 个种类设置标签对应 0、1、2、3、4。横纵坐标对应玉米病害的标签, 横坐标表示预测种类的标签, 纵坐标表示真实种类的标签。图 4 所示的是 MobileNetV2 和迁移学习的 MobileNetV2 的训练集识别的混淆矩阵。从图中可以看出, MobileNetV2 对标签为 1 的玉米灰斑病和标签为 3 的玉米叶斑病识别出错的图片数量多(图 4a); 而示迁移学习的 MobileNetV2 大大减少了对标签 1 和标签 3 的错误识别, 因为标签 1 和标签 3 的玉米病害特征相似, 通过改进的迁移学习的方法极大地改善了标签间互相混淆的情况, 通过该方法标签 1 从出错 59 张降低到 39 张, 标签 3 从出错 93 张降低到 40 张, 有效提高了对玉米病害训练集的准确率。

**表 4　6 种模型进行玉米病害识别的测试结果**

Table 4　Recognition results of maize diseases by six models

| 模型名称 Model name | 训练集准确率 Training set accuracy (%) | 验证集准确率 Validation set accuracy (%) | 权重大小 Weight size (MB) | 参数数量 Number of parameters | 运行时间 Run time (s) |
|---|---|---|---|---|---|
| AlexNet | 95.24 | 93.88 | 55.67 | 14 591 685 | 2 830 |
| GooleNet | 96.38 | 95.48 | 39.39 | 10 318 655 | 10 400 |
| Vgg16 | 95.05 | 91.69 | 158.17 | 41 460 549 | 51 800 |
| RestNet34 | 96.17 | 97.67 | 81.31 | 21 287 237 | 12 550 |
| MobileNetV2 | 94.86 | 96.21 | 8.69 | 2 230 277 | 9 050 |
| Migrated MobileNetV2 | 94.62 | 97.23 | 8.69 | 2 230 277 | 2 700 |

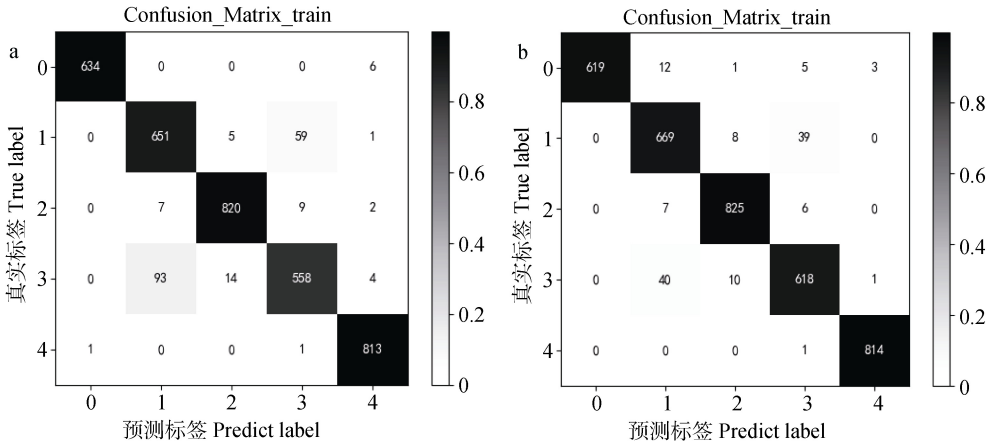


**图 4　MobileNetV2 训练集(a)和迁移的 MobileNetV2 训练集(b)的混淆矩阵**

Fig. 4　Confusion matrixes of MobileNetV2 training set (a) and migrated MobileNetV2 training set (b)

标签 0、1、2、3、4 和 5 分别对应健康玉米、玉米灰斑病、玉米锈病、玉米叶斑病、玉米矮花叶病毒病。Label 0, 1, 2, 3, 4 and 5 correspond to healthy maize, maize gray leaf spots, maize rust, maize leaf spots and maize dwarf mosaic disease, respectively.

### 3.2　验证集的混淆矩阵

使用 MobileNetV2 和迁移的 MobileNetV2 方法对玉米病害 Corn 数据集中的测试集进行识别、制作混淆矩阵, 如图 5 所示。从图中可以看出, 迁移的 MobileNetV2 对玉米病害 Corn 数据集中的测试集识别准确率大大提升, 图 5a 中标签 3 的玉米叶斑病的识别较差的出错张数从 17 张降低到 10 张(图 5b)。

### 3.3　玉米病害训练集的损失曲线

迁移的 MobileNetV2 方法, 通过 Facal Loss 函数改进神经网络的损失函数, AlexNet、GooleNet、Vgg16、RestNet34 和 MobileNetV2 这 5 种模型使用的 Cross Entropy Loss 交叉熵损失函数, 训练迭代 50 次。通过图 6 发现迁移的 MobileNetV2 曲线比其他模型的损失率低, 经过第 10 次迭代损失趋于稳定。用 Facal Loss 函数改进卷积神经网络对不均匀小样本训练效果更好, 具有更强的抗干扰性和鲁棒性。

### 3.4　玉米病害验证集的准确率曲线

从图 7 可以看出, 迁移的 MobileNetV2 对玉米病害 Corn 数据集验证集识别的准确率高, 对玉米病害的验证集的 50 次迭代准确率处于稳定状态。由于玉米病害样本小, AlexNet、GooleNet、Vgg16、RestNet34 和 MobileNetV2 模型不能充分训练, 卷积神经网络对验证集的识别准确率不稳定。迁移的 MobileNetV2 通过在 ImageNet 数据集上训练权重参数, 迁移到玉米病害 Corn 数据集进行训练微调, 对

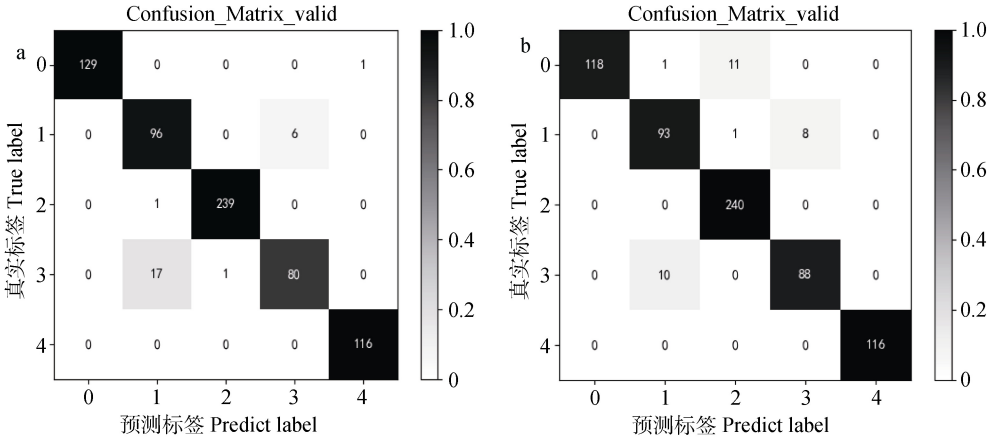


**图 5 MobileNetV2 验证集的混淆矩阵(a)和迁移的 MobileNetV2 的混淆矩阵(b)**

Fig. 5 Confusion matrixes of the MobileNetV2 verification set (a) and migrated MobileNetV2 verification set (b)

标签 0、1、2、3、4 和 5 分别对应健康玉米、玉米灰斑病、玉米锈病、玉米叶斑病、玉米矮花叶病毒病。Label 0, 1, 2, 3, 4 and 5 correspond to healty maize, maize gray leaf spots, maize rust, maize leaf spots and maize dwarf mosaic disease, respectively.

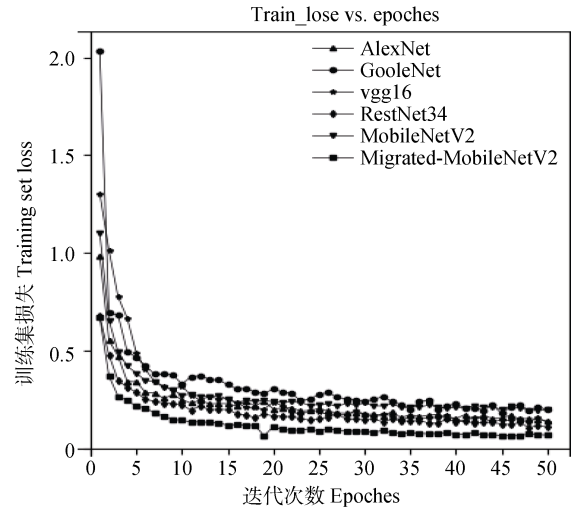


**图 6 6 种模型训练集进行 50 次迭代的损失曲线**

Fig. 6 Loss curves of the training set for 50 iterations of six models

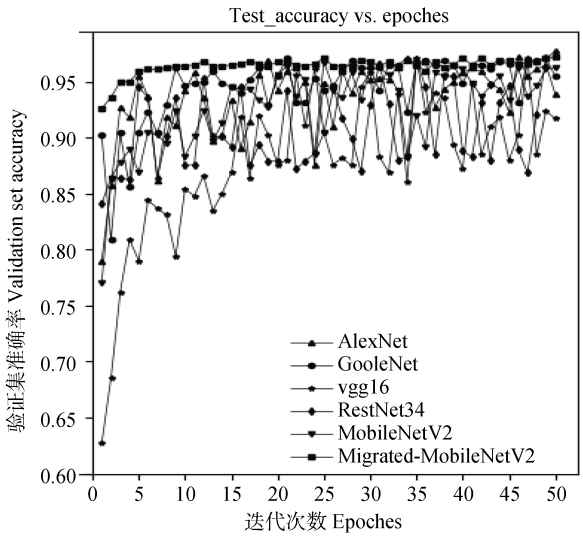


**图 7 6 种模型验证集进行 50 次迭代的损失曲线**

Fig. 7 Loss curves of the validation set for 50 iterations of six models

验证集的识别准确率稳定。由此可以说明，对模型进行训练时参数迁移的方法比参数初始化的效果好。在 ImageNet 数据集上训练权重参数，数据集种类多，因此迁移学习的方法泛化能力强。

## 4 结论

作物病虫害防治是农业生产的重要组成部分。为了克服小样本玉米病害识别的困难，本文引入迁移学习方法，提高了识别准确度。选取基于 Corn 的玉米病害数据集作为研究对象，进行了一系列试验和探索，得出以下结论:

1) Corn 数据集样本数据分布不均匀，运用了旋转、翻转、中心裁剪等方法进行数据增强处理，得到强化后的玉米病害数据集，通过数据增强弱化背景，使得病害特征明显。

2)针对增强后数据集标签 0 的健康玉米和标签 1 的玉米灰斑病训练集样本过少的问题，进行了翻转扩容处理，通过 Facal Loss 损失函数解决 5 种玉米病害标签样本数量不均匀的问题，训练集的准确率从 92.77%提升到 94.62%，该方法能够有效提升玉米病害训练集识别准确率。

3)采用 Pytorch 框架作为试验环境，通过对 6 种模型进行试验，结果显示迁移的 MobileNetV2 方法对玉米病害验证集的识别率高达 97.23%，参数模型仅有 8.69 MB，样本训练时间仅有 2 700 s，对于此次采用的小样本玉米病害数据集迁移的 MobileNetV2 方法最有效，具有权重小、准确率高、鲁棒性强的特点，能够避免过拟合的现象，可以应用到小样本的玉米病害识别。

4)将本文采用的迁移的 MobileNetV2 方法与 MobileNetV2 在玉米病害验证集上进行测试, 通过建立混淆矩阵发现标签 1 的玉米灰斑病和标签 3 的玉米叶斑病错误识别张数较多, 而迁移的 MobileNetV2 方法标签 1 从出错 59 张降低到 39 张, 标签 3 从出错 93 张降低到 40 张, 有效地提高了对玉米病害训练集的准确率。

5)迁移的 MobileNetV2 方法通过 Facal Loss 函数改进神经网络的损失函数, AlexNet、GooleNet、Vgg16、RestNet34 和 MobileNetV2 这 5 种模型使用的 Cross Entropy Loss 交叉熵损失函数, 训练迭代 50 次。绘制玉米病害训练集的损失曲线和玉米病害验证集的准确率曲线, 发现迁移的 MobileNetV2 曲线比其他模型的损失率低, 对玉米病害 Corn 数据集验证集识别的准确率高并且稳定, 改进迁移的 MobileNetV2 模型具有更好的鲁棒性和抗干扰性。

本文不足之处是标签为 1 的玉米灰斑病和标签为 3 的玉米叶斑病, 两种玉米病害的有效特征存在局部区域中, 迁移的 MobileNetV2 模型的识别正确率偏低。下一步的研究工作是怎样提高两种玉米病害相似特征的细粒度分类, 通过玉米病害的有效识别在病害发生初期遏制病害的蔓延。

## 参考文献 References


[1] 李道亮. 智慧农业: 中国的机遇和挑战[J]. 高科技与产业化, 2015, 11(5): 42–45
LI D L. Smart agriculture: Opportunities and challenge for China[J]. High-Technology and Industrialization, 2015, 11(5): 42–45

[2] 李冠林, 马占鸿, 王海光. 基于支持向量机的小麦条锈病和叶锈病图像识别[J]. 中国农业大学学报, 2012, 17(2): 72–79
LI G L, MA Z H, WANG H G. Image recognition of wheat stripe rust and wheat leaf rust based on support vector machine[J]. Journal of China Agricultural University, 2012, 17(2): 72–79

[3] 李震, 洪添胜, 曾祥业, 等. 基于 K-means 聚类的柑橘红蜘蛛图像目标识别[J]. 农业工程学报, 2012, 28(23): 147–153
LI Z, HONG T S, ZENG X Y, et al. Citrus red mite image target identification based on K-means clustering[J]. Transactions of the Chinese Society of Agricultural Engineering, 2012, 28(23): 147–153

[4] 许良凤, 徐小兵, 胡敏, 等. 基于多分类器融合的玉米叶部病害识别[J]. 农业工程学报, 2015, 31(14): 194–201
XU L F, XU X B, HU M, et al. Corn leaf disease identification based on multiple classifiers fusion[J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(14): 194–201

[5] TURKOĞLU M, HANBAY D. Plant disease and pest detection using deep learning-based features[J]. Turkish Journal of Electrical Engineering and Computer Sciences, 2019, 27(3): 1636–1651

[6] LECUN Y, BOTTOU L. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278–2324

[7] KRIZHEVSKY A, SUTSKEVE R I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Proceedings of the 25th International Conference on Neural Information Processing Systems. La Jolla, CA: Neural Information Processing Systems Foundation, 2012: 1097–1105

[8] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. [2019-02-10]. https://arxiv.org/pdf/1409.1556.pdf.

[9] SZEGEDY C, LIU W, JIA Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston, MA, USA: IEEE, 2015: 1–9

[10] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA: IEEE, 2016: 770–778

[11] MOHANTY S P, HUGHES D P, SALATHÉ M. Using deep learning for image-based plant disease detection[J]. Frontiers in Plant Science, 2016, 7: 1419

[12] WANG G, SUN Y, WANG J X. Automatic image-based plant disease severity estimation using deep learning[J]. Computational Intelligence and Neuroscience, 2017, 2017: 2917536

[13] OPPENHEIM D, SHANI G, ERLICH O, et al. Using deep learning for image-based potato tuber disease detection[J]. Phytopathology, 2019, 109 (6): 1083–1087

[14] SLADOJEVIC S, ARSENOVIC M, ANDERLA A, et al. Deep neural networks based recognition of plant diseases by leaf image classification[J]. Computational Intelligence and Neuroscience, 2016, 2016: 3289801

[15] 李勇, 刘战东, 张海军. 不平衡数据的集成分类算法综述[J]. 计算机应用研究, 2014, 31(5): 1287–1291
LI Y, LIU Z D, ZHANG H J. Review on ensemble algorithms for imbalanced data classification[J]. Application Research of Computers, 2014, 31(5): 1287–1291

[16] 刘悦婷, 孙伟刚, 张发菊. 一种新的近邻密度 SVM 不平衡数据集分类算法[J]. 贵州大学学报: 自然科学版, 2019, 36(3): 75–80
LIU Y T, SUN W G, ZHANG F J. Imbalanced dataset classification algorithm based on NNDSVM[J]. Journal of Guizhou University: Natural Sciences, 2019, 36(3): 75–80

[17] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]//Proceedings of the 32nd International Conference on International Conference on Machine Learning (ICML). Lille: ACM, 2015: 448–456

[18] PAN S J, YANG Q. A survey on transfer learning[J]. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345–1359

[19] HINTON G E, SRIVASTAVA N, KRIZHEVSKY A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. Computerence, 2012, 3(4): 212–223

[20] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]//2017 IEEE International Conference on Computer Vision (ICCV). Venice, Italy: IEEE, 2017: 2999–3007